13º Congresso Nacional de Engenharia Mecânica
10 a 14 de agosto de 2026, São Luís (MA)

CONEM2026-0311
IDENTIFICAÇÃO DE DANOS EM COMPÓSITOS VIA INTELIGÊNCIA ARTIFICIAL: UMA REVISÃO DE MÉTODOS BASEADOS EM VIBRAÇÃO

Davi Toledo da Costa, dtcbsb@gmail.com[1]
Sergio Henrique da Silva Carneiro, shscarneiro@unb.br[2]

[1,2]Faculdade de Ciências e Tecnologias em Engenharia (FCTE), Universidade de Brasília (UnB), 72444-240, Gama, DF, Brasil

Resumo: Materiais compósitos desempenham um papel central na engenharia aeroespacial devido à elevada resistência específica e rigidez customizável. No entanto, apresentam mecanismos de falha complexos, como a delaminação e a fissuração de matriz, que são de difícil detecção por métodos de inspeção tradicionais e exigem a inatividade da aeronave. Nesse cenário, o Monitoramento da Integridade Estrutural (Structural Health Monitoring - SHM) baseado na resposta vibracional consolida-se como alternativa viável para diagnósticos contínuos. A transição dessas tecnologias para aplicações operacionais enfrenta desafios relacionados à certificação aeronáutica e ao custo computacional. O objetivo deste trabalho é apresentar uma revisão da literatura recente sobre a aplicação de Inteligência Artificial e meta-heurísticas na identificação de danos em compósitos via análise modal e de vibrações. A pesquisa analisou 85 trabalhos, categorizando a literatura em duas abordagens principais: formulação baseada no problema inverso de otimização e reconhecimento de padrões via aprendizado de máquina. A avaliação adotou critérios de interpretabilidade física, custo computacional, dependência de dados empíricos e robustez a variações operacionais. Os resultados indicam que os métodos de otimização oferecem alta explicabilidade, mas apresentam custo computacional limitante devido à severa não-convexidade do problema inverso. Em contrapartida, métodos puramente orientados a dados (Data-Driven) possuem baixa latência, mas apresentam o caráter de caixa-preta (limitando certificações) e sofrem degradação de desempenho em testes empíricos devido à lacuna de realidade (Reality Gap) atrelada às dinâmicas de amortecimento não-linear. O estudo sugere que o avanço tecnológico no setor depende do desenvolvimento de modelos híbridos, com destaque para as Redes Neurais Informadas pela Física (Physics-Informed Neural Networks - PINNs). Demonstra-se como as PINNs incorporam as equações da dinâmica estrutural no processo de treinamento, reduzindo a dependência de dados experimentais e favorecendo a interpretabilidade, embora exijam tratamento algorítmico avançado para instabilidades de gradiente, conforme descrito pela teoria do Kernel Neural Tangente (Neural Tangent Kernel - NTK).

Palavras-chave: Materiais Compósitos, Detecção de Danos, Problema Inverso, Redes Neurais Informadas pela Física, Análise Modal, Certificação Aeronáutica

1. INTRODUÇÃO E COMPLEXIDADE ESTRUTURAL NA AERONÁUTICA

A busca por maior eficiência aerodinâmica e redução do consumo de combustível estabeleceu os materiais compósitos laminados, particularmente os polímeros reforçados com fibra de carbono (Carbon Fiber Reinforced Polymers - CFRP), como elementos primários na engenharia aeroespacial contemporânea. Estruturas como fuselagem, empenagens e componentes das asas utilizam esses materiais devido às suas propriedades anisotrópicas favoráveis e alta relação peso-resistência. No entanto, a natureza laminada e heterogênea dos compósitos introduz modos de falha distintos do comportamento isotrópico típico dos metais estruturais tradicionais.

Enquanto metais como alumínio e titânio apresentam propagação de trinca majoritariamente superficial, os compósitos dissipam energia de impacto através de falhas variadas, que incluem microfissuras na matriz polimérica, descolamento da interface fibra-matriz, ruptura de fibras e, principalmente, a delaminação interlaminar (Gomes *et al.*, 2020b).

A delaminação caracteriza-se por separações internas entre as camadas adjacentes do laminado, frequentemente causadas por Impactos de Baixa Velocidade (Low-Velocity Impact - LVI) ou concentrações de tensões de cisalhamento. Sob a ótica micromecânica, o LVI cria um cone de delaminação interno quando o pico das tensões de cisalhamento interlaminar (τ_{xz}, τ_{yz}) excede a resistência de ruptura da matriz epóxi. Por ser uma falha interna, é tipicamente imperceptível na superfície, fenômeno conhecido na indústria como Dano de Impacto Imperceptível Visualmente (Blind Visual Impact Damage - BVID), o qual pode reduzir a resistência residual à compressão da estrutura em até 60%. De acordo com a Teoria Clássica de Placas Laminadas (Classical Laminated Plate Theory - CLPT), a introdução dessa delaminação provoca uma queda drástica nos coeficientes da matriz de rigidez à flexão ($[D]$) do compósito, o que justifica fisicamente a alteração

nas frequências naturais e nas formas modais do componente detectadas pelos sensores.

Tendo em vista que inspeções convencionais baseadas em Ensaios Não Destrutivos (Non-Destructive Testing - NDT), como ultrassom (C-Scan) e termografia ativa (Katunin *et al.*, 2015; Oliveira *et al.*, 2024), exigem a retirada da aeronave de operação, os custos associados ao tempo de inatividade (*downtime*) tornam-se um limitante logístico. Para mitigar essa restrição, o setor aeroespacial tem investido no SHM. O SHM propõe a transição da manutenção programada para a manutenção preditiva baseada em condição, empregando redes de sensores integradas à estrutura para fornecer diagnósticos autônomos contínuos (Rahul *et al.*, 2019; Sause and Jasiūnienė, 2021).

Dentre as metodologias de SHM, as técnicas baseadas em vibração global e análise modal viabilizam a avaliação de grandes áreas estruturais a partir de um número reduzido de sensores piezelétricos de titanato zirconato de chumbo (Lead Zirconate Titanate - PZT) ou acelerômetros (Gomes *et al.*, 2018d; Mello *et al.*, 2024). O princípio físico subjacente é direto: a introdução de uma descontinuidade local (dano) altera as propriedades mecânicas da estrutura, reduzindo sua rigidez elástica ou modificando suas matrizes de massa e amortecimento. Tais alterações resultam em perturbações quantificáveis nas características dinâmicas do sistema (Stepinski *et al.*, 2013; Farrar *et al.*, 1996). Variações em frequências naturais, formas modais, energia de deformação modal e Funções de Resposta em Frequência (Frequency Response Functions - FRF) têm sido investigadas como parâmetros de falha (Owolabi *et al.*, 2003; Bandara *et al.*, 2014).

Contudo, nota-se uma discrepância relevante entre os cenários de validação acadêmica e a aplicação industrial. A maior parte dos algoritmos de detecção de dano na literatura é validada em geometrias de baixa complexidade, como vigas engastadas ou placas planas simples. Em contrapartida, as estruturas aeronáuticas reais apresentam maior nível de complexidade.

Um painel de fuselagem, por exemplo, não é uma placa ortotrópica simples, mas uma estrutura curva e enrijecida por longarinas longitudinais e cavernas transversais, unidas por elementos de fixação mecânica ou processos de co-cura. Esses componentes inserem não-linearidades ao sistema: conexões podem gerar amortecimento friccional, e os reforçadores afetam a dispersão geométrica das ondas mecânicas. Além disso, a ocorrência de danos múltiplos simultâneos gera superposições espectrais que limitam o desempenho de algoritmos lineares clássicos. A implementação de sistemas de SHM no ambiente industrial requer que as ferramentas computacionais consigam tolerar essas complexidades estruturais, impulsionando a adoção de métodos baseados em Inteligência Artificial (Alves *et al.*, 2024).

2. METODOLOGIA E CRITÉRIOS DE AVALIAÇÃO PARA CERTIFICAÇÃO

Para investigar o estado da arte do SHM em compósitos, esta pesquisa adotou uma revisão sistemática abrangendo inicialmente 312 documentos publicados entre 2010 e 2025, que, após a aplicação dos critérios de exclusão detalhados no fluxograma resultou em um corpus de 85 trabalhos científicos. A primeira etapa consistiu em buscas nas bases Scopus, Web of Science e IEEE Xplore, seguidas pelo método de amostragem em bola de neve (*snowballing*) a partir das referências dos artigos selecionados. A filtragem adaptou as diretrizes dos Itens Preferenciais para Relatórios de Revisões Sistemáticas e Metanálises (Preferred Reporting Items for Systematic Reviews and Meta-Analyses - PRISMA), priorizando, além de métricas bibliométricas, a viabilidade de aplicação em contextos de certificação aeronáutica. O fluxograma metodológico é apresentado na Fig. 1.

A etapa final da pesquisa consistiu na aplicação de critérios técnicos alinhados à engenharia de confiabilidade aeronáutica. Muitos métodos alcançam alta precisão em simulações numéricas ideais; no entanto, a aplicação prática exige conformidade com as restrições impostas por autoridades reguladoras (como a Agência Nacional de Aviação Civil - ANAC e a Federal Aviation Administration - FAA). Visando estimar o Nível de Maturidade Tecnológica (Technology Readiness Level - TRL) das soluções, os artigos selecionados foram avaliados sob quatro parâmetros técnicos principais:

- Interpretabilidade Física e Certificação: Avalia a capacidade de relacionar causalmente a saída do algoritmo a princípios da mecânica da fratura. Normas para sistemas embarcados críticos, como a DO-178C, restringem o uso de modelos do tipo caixa-preta (*black-box*). Adicionalmente, sistemas de SHM que visam substituir os métodos de inspeção NDT em estruturas primárias precisam atingir rigorosos Níveis de Garantia de Projeto (Design Assurance Levels - DAL), como o DAL A ou DAL B, para atestar a segurança em voo. A transição para níveis TRL mais altos exige o cálculo da Probabilidade de Detecção (Probability of Detection - PoD) (Sause and Jasiūnienė, 2021), essencial para estimar o tamanho mínimo de delaminação que o sistema é capaz de identificar, em conformidade com o padrão NDT da indústria (Katunin *et al.*, 2015; Oliveira *et al.*, 2024).

- Custo Computacional e Latência: Considera a viabilidade de processamento do algoritmo em hardwares embarcados executando processamento na borda (*edge computing*) com severas restrições de peso e energia, sendo fundamental para o monitoramento contínuo em tempo real (Pant *et al.*, 2021).

- Dependência de Dados (*Data Hunger*): Analisa o volume de dados empíricos rotulados exigidos para o treinamento. Na indústria aeroespacial, dados operacionais de falhas estruturais reais são escassos e dispendiosos de se obter (Ofir *et al.*, 2025).

- Robustez a Variações Operacionais e Ambientais (Environmental and Operational Variabilities - EOV): Considera a imunidade do sistema a perturbações externas. Variações térmicas severas durante o voo podem alterar as propriedades de rigidez do CFRP, provocando deslocamentos na resposta vibracional que mascaram o sinal característico do BVID estrutural (Padil *et al.*, 2019).

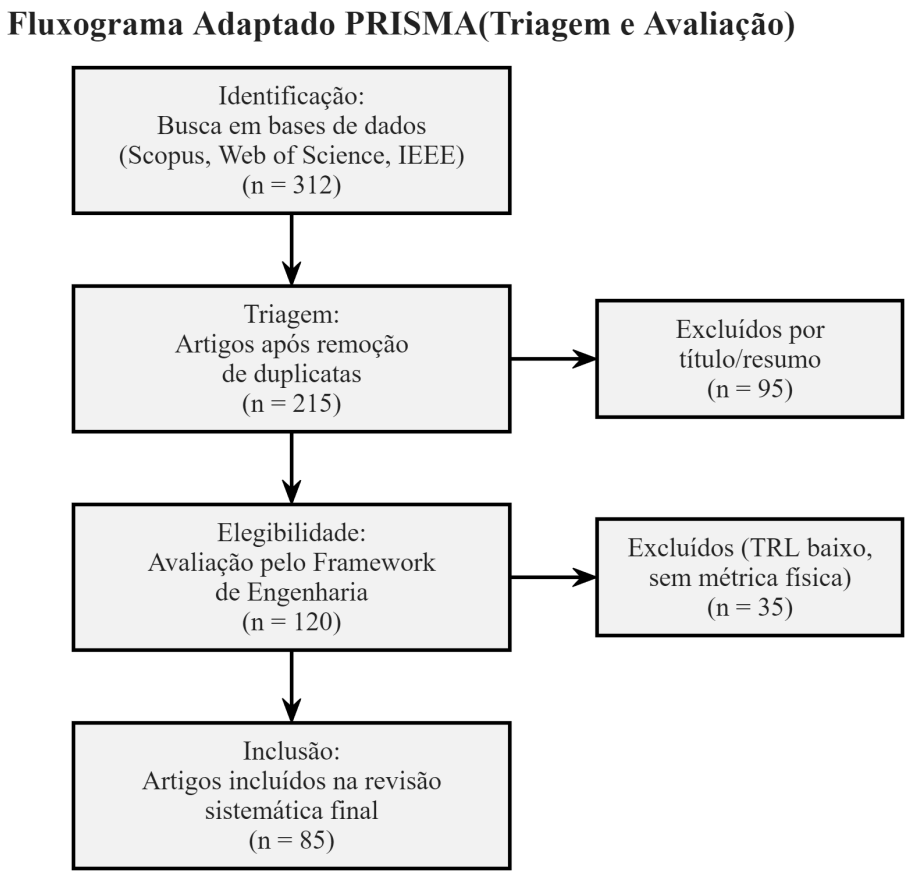

Figura 1: Fluxograma metodológico de triagem das publicações, baseado em métodos sistemáticos de filtragem.

3. ANÁLISE QUANTITATIVA DA LITERATURA

A análise da literatura revela uma evolução metodológica no campo do SHM nos últimos quinze anos, caracterizada pela transição de abordagens analíticas e de otimização clássica para arquiteturas orientadas a dados (*Data-Driven*) e modelos híbridos. A distribuição cronológica dessas abordagens é sumarizada na Fig. 2.

A Tabela 1 apresenta a classificação dos artigos selecionados segundo as variáveis físicas de entrada (*features*), a metodologia algorítmica e o grau de complexidade da estrutura investigada. A análise desta tabela destaca o *gap* entre a pesquisa orientada a dados, validada predominantemente em geometrias simplificadas, e a necessidade real de estruturas aeronáuticas que incorporam reforçadores e junções rebitadas. Do ponto de vista da física de ondas, a presença de longarinas (*stringers*) e cavernas (*frames*) atua como guias de onda mecânicos que causam reflexão, refração e espalhamento (*scattering*). Esse fenômeno cria um efeito de múltiplos caminhos (*multipath*) com interferências construtivas e destrutivas severas nos sinais vibracionais globais da placa. É por esse exato motivo físico que topologias de redes neurais simples não conseguem separar com confiabilidade o que é a reflexão normal de um rebite estrutural do que é a reflexão gerada por uma trinca.

A avaliação sistemática, complementada pela proporção visualizada na Fig. 3, evidencia um desafio voltado à certificação. Embora correspondam a 44,7% das publicações, os métodos *Data-Driven* frequentemente carecem das restrições físicas necessárias para discriminar perturbações provenientes de EOV (como mudanças bruscas de temperatura) de perdas reais de rigidez local. Essa característica limita a aplicabilidade desses modelos diante das normativas da aviação civil.

O panorama literário indica um *trade-off* clássico na engenharia: modelos baseados na física (otimização iterativa) possuem explicabilidade satisfatória para certificação, mas alto custo computacional, ao passo que modelos *Data-Driven* oferecem inferência rápida, mas carecem de fundamentação fenomenológica. Esse cenário impulsionou a recente pesquisa em torno de abordagens híbridas.

4. O PROBLEMA INVERSO VIA OTIMIZAÇÃO E SUAS LIMITAÇÕES

Uma parcela significativa das abordagens de SHM (21,2% do corpus) modela a identificação de danos como um problema inverso de otimização, processo amplamente definido na literatura como Atualização de Modelos de Elementos Finitos (Finite Element Model Updating - FEM Updating) (Gomes *et al.*, 2016a; Magacho *et al.*, 2021).

Nessa formulação, a estrutura aeronáutica é representada por um modelo computacional paramétrico pelo Método dos Elementos Finitos (Finite Element Method - FEM). O dano é tipicamente modelado como uma redução quantitativa (escalar de 0 a 1) nos coeficientes da matriz de rigidez dos elementos do compósito. O processo busca a configuração

Tabela 1: Taxonomia da literatura revisada: Classificação detalhada por abordagem e aplicação estrutural (85 artigos).

Abordagem Metodológica	Principais Variáveis (*Features*)	Tipo de Estrutura	Referências do Corpus
Otimização e Problema Inverso	Frequências Naturais, Formas Modais e MAC	Placas de CFRP, Vigas e Treliças 3D	(Gomes *et al.*, 2018c), (Gomes *et al.*, 2018b), (Guan *et al.*, 2017), (Gomes and Giovani, 2020), (Gomes *et al.*, 2018a), (Gomes *et al.*, 2020a), (Gomes *et al.*, 2016a), (Gomes *et al.*, 2016c), (Magacho *et al.*, 2021), (Gomes *et al.*, 2020b), (Pereira *et al.*, 2020), (Araújo dos Santos *et al.*, 2000), (Jafarkhani and Masri, 2011), (Ebrahimian *et al.*, 2017), (Gomes and Pereira, 2020), (Gomes *et al.*, 2018d), (Gomes, 2017), (Gomes *et al.*, 2016b), (Zhang *et al.*, 2018), (Braun *et al.*, 2015)
Aprendizado de Máquina (*Data-Driven*)	FRF, Sinais Brutos, PCA e CNNs	Painéis de Fuselagem, Asa de Avião e Pontes	(Dworakowski *et al.*, 2016), (Hossain *et al.*, 2017), (Gomes, 2024), (Cha *et al.*, 2017), (Ihesiulor *et al.*, 2013), (Eftekhar Azam *et al.*, 2018), (Bakhary *et al.*, 2007), (Padil *et al.*, 2019), (Gomes *et al.*, 2019), (Oliver *et al.*, 2020), (Zang and Imregun, 2001), (Abdeljaber *et al.*, 2017), (Geng *et al.*, 2018), (Khan *et al.*, 2019), (Guemes *et al.*, 2025), (Khodabandehlou *et al.*, 2018), (Pereira *et al.*, 2019), (Barai and Pandey, 2012)
Processamento de Sinais e Métodos Analíticos	Wavelets (CWT/DWT), Energia Modal e LDV	Vigas Laminadas, Pás Eólicas e Eixos	(Fan and Qiao, 2012), (Xiang and Liang, 2012), (de Sousa *et al.*, 2018), (Gomes *et al.*, 2017), (Owolabi *et al.*, 2003), (Elshamy *et al.*, 2018), (Tributsch and Adam, 2017), (Dessi and Camerlengo, 2014), (Rucevskis *et al.*, 2016), (Doliński *et al.*, 2018), (Bovsunovsky, 2018), (Khan *et al.*, 2022), (Alaimo, 2018), (Karsh *et al.*, 2018), (Bandara *et al.*, 2014), (Nimje, 2016), (Oliver *et al.*, 2022), (Cawley and Adams, 1979), (Yin *et al.*, 2017), (de Azevedo *et al.*, 2017), (Vila *et al.*, 2024), (Oliver, 2021)
Modelos Híbridos e Machine Learning Científico	PINNs, NTK e Digital Twins	Estruturas de Segurança Crítica	(Tavares *et al.*, 2024), (Alves *et al.*, 2024), (Mello *et al.*, 2024), (Cuomo *et al.*, 2022), (Khalid *et al.*, 2024), (Wang *et al.*, 2020)
Fundamentação Teórica e Revisões de SHM	NDT, TRL e Certificação Aeronáutica	Sistemas Aeroespaciais Gerais	(Stepinski *et al.*, 2013), (Souza and Nóbrega, 2016), (Gopalakrishnan S., 2011), (Farrar and Worden, 2012), (Farrar *et al.*, 1996), (Katunin *et al.*, 2015), (Boller, 2000), (Raut *et al.*, 2021), (Pant *et al.*, 2021), (Rocha *et al.*, 2021), (Ofir *et al.*, 2025), (Rahul *et al.*, 2019), (Pollock *et al.*, 2021), (Yuan, 2016), (Sause and Jasiūnienė, 2021), (Fan and Qiao, 2011), (Oliveira *et al.*, 2024), (Gomes *et al.*, 2018e)

de dano no modelo numérico FEM que gere uma resposta vibracional correspondente aos sinais empíricos extraídos da estrutura real.

Do ponto de vista físico e matemático, a função objetivo deste problema é caracterizada por ser severamente não-convexa e multimodal. Devido às simetrias espaciais inerentes aos painéis laminados e à possibilidade de ocorrência de múltiplos danos simultâneos na estrutura, a topologia da função de erro possui incontáveis mínimos locais. Em decorrência dessa não-convexidade paramétrica, métodos clássicos de solução baseados na descida do gradiente divergem ou convergem para falsos positivos.

Para superar essa não-convexidade e convergir para o cenário real, a literatura faz uso obrigatório de algoritmos meta-heurísticos estocásticos globais, como Algoritmos Genéticos (Genetic Algorithms - GA) (Gomes *et al.*, 2016b), Otimização por Colônia de Formigas (Ant Colony Optimization - ACO) (Braun *et al.*, 2015), Otimização do Girassol (Sunflower Optimization - SFO) (Gomes and Giovani, 2020; Gomes *et al.*, 2020b) e Algoritmo de Lichtenberg (Pereira *et al.*, 2020). A função objetivo $J(\theta)$ minimiza os resíduos entre as respostas dinâmicas medidas experimentalmente (*exp*) e simuladas numericamente (*num*). A formulação frequentemente incorpora diferenças relativas nas frequências naturais (ω_i) e a correlação das formas modais expressa pelo Critério de Garantia Modal (Modal Assurance Criterion - MAC) (Khan *et al.*, 2022) como demonstrada abaixo na Eq.(1):

$$J(\theta) = \sum_{i=1}^{n} W_{\omega i} \left(\frac{\omega_i^{exp} - \omega_i^{num}(\theta)}{\omega_i^{exp}} \right)^2 + \sum_{i=1}^{n} W_{\phi i} (1 - MAC(\phi_i^{exp}, \phi_i^{num}(\theta)))^2 \tag{1}$$

Onde θ representa o vetor de parâmetros avaliados e W são os fatores de ponderação. Derivações dessa função frequentemente substituem frequências genéricas por métricas como curvatura modal ou energia de deformação, devido à sua maior sensibilidade geométrica a danos localizados (Fan and Qiao, 2012; Dessi and Camerlengo, 2014; Rucevskis *et al.*, 2016).

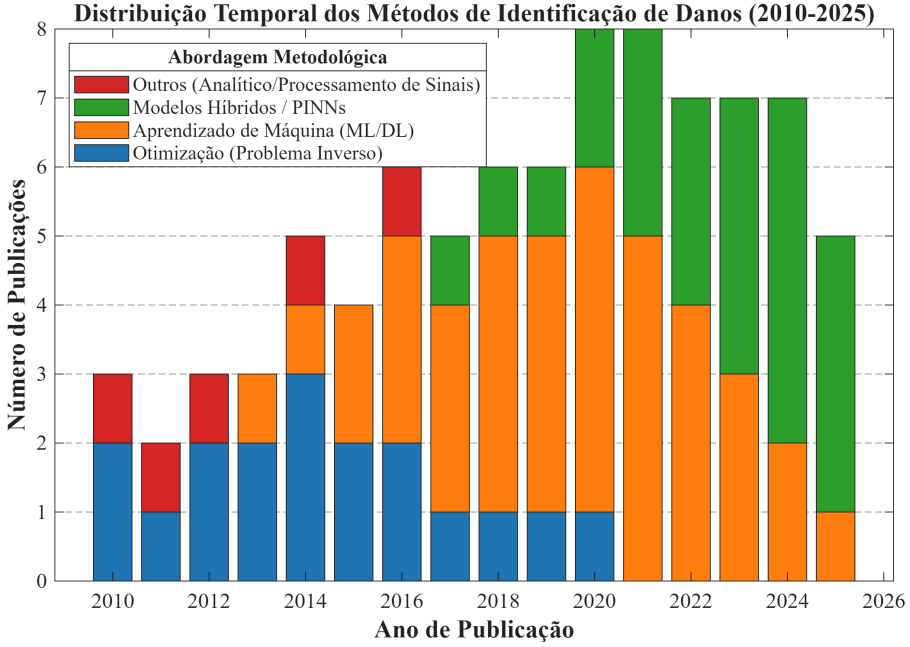

Figura 2: Distribuição temporal dos métodos de identificação de danos avaliados entre os anos de 2010 e 2025.

A principal vantagem desse método para uso aeroespacial é a sua explicabilidade. O laudo gerado aponta de forma determinística a redução da constante elástica e as coordenadas exatas do dano, cumprindo requisitos formais de causalidade.

A principal limitação, no entanto, é a latência computacional. A avaliação repetitiva de modelos FEM com um alto número de graus de liberdade imposta pelas populações das meta-heurísticas requer longos tempos de processamento, tornando essa abordagem majoritariamente viável para avaliações *offline* no solo, e dificultando sua aplicação para monitoramento embarcado contínuo.

5. MÉTODOS DATA-DRIVEN E O REALITY GAP

Para contornar o custo computacional atrelado ao FEM Updating, a pesquisa nos últimos anos direcionou-se para algoritmos baseados exclusivamente na inferência de dados (44,7% das publicações revisadas). Essa categoria prioriza modelos de Redes Neurais Artificiais (Artificial Neural Networks - ANN) e Redes Neurais Convolucionais (Convolutional Neural Networks - CNN) (Abdeljaber *et al.*, 2017; Khan *et al.*, 2019; Khodabandehlou *et al.*, 2018). O foco computacional desloca-se da resolução explícita de equações dinâmicas para a identificação de correlações não lineares extraídas diretamente de matrizes de sensoriamento contínuo, como os dados fornecidos por Redes de Bragg em Fibra (Fiber Bragg Grating - FBG).

No pré-processamento para tais modelos, métodos convencionais baseados em FRF são progressivamente substituídos por técnicas matemáticas, como a Análise de Componentes Principais (Principal Component Analysis - PCA) (Zang and Imregun, 2001) e transformações espaço-frequenciais, com destaque para as Transformadas Wavelet Contínuas (Continuous Wavelet Transforms - CWT) e Discretas (Discrete Wavelet Transforms - DWT) (Doliński *et al.*, 2018; Oliver *et al.*, 2022; Vila *et al.*, 2024; Oliver, 2021).

A formulação analítica da CWT em relação a um sinal de deflexão estrutural $x(t)$ é expressa na Eq.(2) abaixo por:

$$W(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t)\psi^* \left(\frac{t-b}{a} \right) dt \tag{2}$$

Onde $\psi(t)$ é a wavelet-mãe. O parâmetro de escala a controla a dilatação da função e o parâmetro de translação b mapeia a localização espacial da perturbação. Como as delaminações reduzem localmente a rigidez flexional, originando perturbações pontuais, os mapas de coeficientes gerados pela CWT são particularmente sensíveis e servem como matrizes de entrada otimizadas para os filtros de uma CNN (Cha *et al.*, 2017).

Apesar de diversos estudos documentarem altas taxas de precisão em predições baseadas em CNNs para painéis simplificados, sua validação para a indústria encontra duas barreiras substanciais. A primeira é de natureza certificatória: o processo de minimização por descida de gradiente estocástico (Stochastic Gradient Descent) sobre uma topologia densa de dados gera predições sem lastro na mecânica dos materiais, enquadrando o algoritmo como caixa-preta.

A segunda barreira é a discrepância fenomenológica observada entre os dados de treinamento sintéticos e os sinais físicos em voo, referenciada na literatura como a lacuna de realidade (*Reality Gap*). Devido ao custo e à raridade de dados experimentais destrutivos na aviação, os modelos de IA são frequentemente treinados em *datasets* numéricos gerados

Proporção das Abordagens Metodológicas (Corpus: 85 Artigos)
Aprendizado de Máquina (44.7%)
Otimização (21.2%)
Modelos Híbridos / PINNs (28.2%)
Outros (5.9%)

Figura 3: Proporção percentual das abordagens metodológicas identificadas na revisão da literatura (Total: 85 artigos).

via FEM. O problema reside na modelagem física do amortecimento. Um software de elementos finitos tipicamente emprega aproximações lineares teóricas, como o amortecimento proporcional de Rayleigh. Em contrapartida, um painel aeronáutico real possui amortecimento friccional não-linear (proveniente do atrito entre chapas e rebites), além de sofrer influência de ruídos aeroelásticos dinâmicos. A rede convolucional, desprovida de restrições físicas, sofre sobreajuste (*overfitting*) nas propriedades lineares idealizadas da simulação. Ao transpor o modelo preditivo para a aeronave física real, as dinâmicas de dissipação não-lineares são incorretamente interpretadas, resultando em uma expressiva degradação no desempenho de identificação do BVID (Geng *et al.*, 2018).

6. ABORDAGENS HÍBRIDAS E REDES NEURAIS INFORMADAS PELA FÍSICA

Os desafios de latência em modelos de otimização não-convexa e a baixa interpretabilidade aliada ao *Reality Gap* de amortecimento nos modelos puramente *Data-Driven* impulsionaram a adoção tecnológica recente das PINNs (Cuomo *et al.*, 2022; Khalid *et al.*, 2024).

As PINNs integram princípios analíticos de dinâmica das estruturas diretamente à formulação algorítmica da rede neural. Equações Diferenciais Parciais (Partial Differential Equations - PDEs), referentes às leis de conservação de momento, comportamento ortotrópico ou à teoria modificada de Mindlin-Reissner, são computadas nos nós da rede e adicionadas como um termo residual de penalização na formulação da função perda geral (Loss Function) como demonstrado abaixo na Eq.(3):

$$\mathcal{L}_{total} = \omega_1 \mathcal{L}_{dados} + \omega_2 \mathcal{L}_{PDE} + \omega_3 \mathcal{L}_{Contorno} \tag{3}$$

O cálculo das derivadas analíticas dos operadores estruturais ($\mathcal{L}_{PDE}$) não requer interpolação em malhas externas, uma vez que se emprega o mecanismo de Diferenciação Automática (Automatic Differentiation). A inclusão da parcela de restrição mecânica na minimização estabiliza o algoritmo perante ruídos não-lineares, reduzindo significativamente a dependência de dados rotulados e permitindo extrapolações preditivas fisicamente consistentes. Esse lastro melhora a viabilidade técnica da rede em processos de auditoria (ex: DO-178C).

Além do diagnóstico instantâneo, a integração de princípios de mecânica da fratura contínua confere aos modelos a capacidade de atuar como Gêmeos Digitais (Digital Twins) (Tavares *et al.*, 2024; Khalid *et al.*, 2024). Isso permite projetar a taxa de propagação do dano ao longo do tempo para o cálculo direto da Vida Útil Restante (Remaining Useful Life - RUL) do componente aeronáutico.

Um fator limitante das PINNs sob investigação acadêmica recente refere-se a problemas de instabilidade na convergência do treinamento, formalmente descritos pela teoria do NTK. A matriz do NTK avalia as propriedades direcionais do gradiente paramétrico θ, como demonstrado abaixo na Eq.(4):

$$K_{NTK}(x, x') = \langle \nabla_\theta f(x, \theta), \nabla_\theta f(x', \theta) \rangle \tag{4}$$

As análises sob a ótica da matriz do kernel demonstram que, para estruturas rígidas características dos compósitos aeroespaciais (CFRP), os autovalores da matriz NTK correspondentes aos modos de vibração global de baixa frequência são ordens de grandeza maiores que os autovalores dos modos locais de alta frequência. Em consequência matemática dessa discrepância espectral, o otimizador da rede sofre de inanição de gradiente (*gradient starvation*). O algoritmo converge rapidamente para mapear a resposta global macroscópica da placa, mas anula prematuramente a magnitude dos gradientes necessários para otimizar e localizar as perturbações de alta frequência relativas ao BVID.

A literatura sugere que essa restrição analítica pode ser mitigada pela integração do processamento via Wavelets à função perda da PINN (Vila *et al.*, 2024; Oliver, 2021; Wang *et al.*, 2020). A proposta técnica introduz máscaras de ponderação de atenção espacial aos nós do domínio PDE baseadas nos mapas numéricos dos coeficientes de alta resolução CWT, formalizando a nova parcela de erro informada pela física ($\mathcal{L}^*_{PDE}$), exemplificada abaixo na Eq.(5) como:

$$\mathcal{L}^*_{PDE} = \frac{1}{N}\sum_{i=1}^{N}\left[1+\alpha|W(x_i,t_i)|\right]\left|\mathcal{F}_\theta(x_i,t_i)\right|^2 \tag{5}$$

Nesta representação, $\mathcal{F}_\theta$ é o operador do laminado avaliado nos pontos de colocação espacial x_i, escalonado por um ganho α. Sob a ótica da engenharia computacional, a Eq.(5) atua como um filtro passa-alta paramétrico da função de perda. Nas áreas operacionais íntegras da placa, os coeficientes de alta frequência da transformada tendem a zero, estabilizando a função com baixo peso ($W \approx 0$). Contudo, na exata coordenada de uma singularidade geométrica originada pela delaminação, a máscara Wavelet acentua localmente e de forma expressiva a taxa de erro residual. Tal arranjo força o algoritmo a alocar os cálculos de descida do gradiente no nó específico da deflexão pontiaguda detectada, superando a inanição de gradiente imposta pelos preceitos do NTK e garantindo a correta detecção do BVID.

7. CONCLUSÕES

O monitoramento contínuo e não intrusivo da integridade estrutural em compósitos reforçados, baseado na análise computacional da resposta vibracional e de assinaturas modais, é um componente importante para a implementação de estratégias de manutenção preditiva na aviação. Essas abordagens contribuem para reduzir o tempo de indisponibilidade operacional das aeronaves e aumentar os níveis de segurança em frotas civis e militares.

A revisão sistemática conduzida neste estudo, baseada na análise de 85 trabalhos recentes, permitiu identificar tanto os avanços quanto as limitações das tecnologias atualmente empregadas no campo do SHM. No contexto das exigências da aviação civil, métodos tradicionais baseados em FEM Updating demonstram elevada capacidade de interpretação física dos fenômenos. Entretanto, sua aplicação em sistemas embarcados é limitada pelo elevado custo computacional necessário para o processamento de algoritmos iterativos não-convexos em tempo real.

Por outro lado, abordagens puramente baseadas em dados (*Data-Driven*), como as CNNs, apresentam elevada eficiência computacional e permitem a detecção de padrões dinâmicos com baixa latência. Contudo, esses modelos frequentemente carecem de interpretabilidade fenomenológica, dificultando sua utilização em processos formais de certificação aeronáutica. Além disso, a literatura aponta degradação de desempenho acentuada desses modelos aplicados a dados empíricos, devido ao *Reality Gap* das dinâmicas de amortecimento não-linear ausentes nos ambientes simulados por elementos finitos e sujeitas a condições de variação operacional EOV.

Nesse contexto, modelos híbridos que integram conhecimento físico e aprendizado de máquina surgem como uma alternativa viável. As PINNs permitem incorporar equações governantes diretamente no processo de otimização das perdas. Essa estratégia reduz a dependência de grandes volumes empíricos e garante a estabilidade física do modelo perante não-linearidades, facilitando a aplicabilidade no meio industrial regulado.

O campo de estudo ainda necessita de avanços metodológicos na estabilização dos treinamentos perante as patologias de inanição de gradiente analisadas pela teoria NTK. A incorporação de processamento avançado de sinais (como filtros espaciais baseados em CWT e DWT) às funções de restrição interna das PINNs demonstra grande potencial para corrigir as discrepâncias espectrais e melhorar o mapeamento do BVID de forma multiescala. Esses desenvolvimentos técnicos convergem para a consolidação de Digital Twins capazes de suportar ativamente a análise preditiva de vida útil restante e os programas de manutenção aeronáutica de nova geração.

8. REFERÊNCIAS

Abdeljaber, O. *et al.*, 2017. "Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks". *Journal of Sound and Vibration*.

Alaimo, A., 2018. "Numerical and experimental study of a shm system for a drop-ply delaminated configuration". *Composite Structures*.

Alves, V.H.M. *et al.*, 2024. "Monitoramento de integridade estrutural utilizando inteligência artificial: desafios, avanços e aplicações". *Revista da Universidade Federal de Minas Gerais*.

Araújo dos Santos, J.V. *et al.*, 2000. "Development of a numerical model for the damage identification on composite plate structures". *Composite Structures*.

Bakhary, N., Hao, H. and Deeks, A.J., 2007. "Damage detection using artificial neural network with consideration of uncertainties". *Engineering Structures*.

Bandara, R.P., Chan, T.H.T. and Thambiratnam, D.P., 2014. "Structural damage detection method using frequency response functions". *Structural Health Monitoring*.

Barai, S.V. and Pandey, P.C., 2012. "Vibration signature analysis using artificial neural networks". *Journal of Computing in Civil Engineering*.

Boller, C., 2000. "Next generation structural health monitoring and its integration into aircraft design". *International Journal of Systems Science*.

Bovsunovsky, A.P., 2018. "Estimation of efficiency of vibration damage detection in stepped shaft of steam turbine". *Electric Power Systems Research*.

Braun, C.E., Chiwiacowsky, L.D. and Gómez, A.T., 2015. "Variations of ant colony optimization for the solution of the structural damage identification problem". *Procedia Computer Science*.

Cawley, P. and Adams, R.D., 1979. "The location of defects in structures from measurements of natural frequencies". *Journal of Strain Analysis*.

Cha, Y.J., Choi, W. and Büyüköztürk, O., 2017. "Deep learning-based crack damage detection using convolutional neural network". *Computer-Aided Civil and Infrastructure Engineering*.

Cuomo, S. *et al.*, 2022. "Scientific machine learning through physics-informed neural networks: Where we are and what's next". *Journal of Scientific Computing*.

de Azevedo, H.D.M. *et al.*, 2017. "Vibration monitoring, fault detection, and bearings replacement of a real wind turbine". *Journal of the Brazilian Society of Mechanical Sciences and Engineering*.

de Sousa, B.S. *et al.*, 2018. "A modified topological sensitivity analysis extended to the design of composite multidirectional laminates structures". *Composite Structures*.

Dessi, D. and Camerlengo, G., 2014. "Damage identification techniques via modal curvature analysis - overview and comparison". *Mechanical Systems and Signal Processing*.

Doliński, L., Krawczuk, M. and Zak, A., 2018. "Detection of delamination in laminate wind turbine blades using one-dimensional wavelet analysis of modal responses". *Shock and Vibration*.

Dworakowski, Z., Dragan, K. and Stepinski, T., 2016. "Artificial neural network ensembles for fatigue damage detection in aircraft". *Journal of Intelligent Material Systems and Structures*.

Ebrahimian, H. *et al.*, 2017. "Nonlinear finite element model updating for damage identification of civil structures using batch bayesian estimation". *Mechanical Systems and Signal Processing*.

Eftekhar Azam, S., Rageh, A. and Linzell, D., 2018. "Damage detection in structural systems utilizing artificial neural networks and proper orthogonal decomposition". *Structural Control and Health Monitoring*.

Elshamy, M., Crosby, W.A. and Elhadary, M., 2018. "Crack detection of cantilever beam by natural frequency tracking using experimental and finite element analysis". *Alexandria Engineering Journal*.

Fan, W. and Qiao, P., 2011. "Vibration-based damage identification methods: A review and comparative study". *Structural Health Monitoring*.

Fan, W. and Qiao, P., 2012. "A strain energy-based damage severity correction factor method for damage identification in plate-type structures". *Mechanical Systems and Signal Processing*.

Farrar, C.R. and Worden, K., 2012. *Structural Health Monitoring: A Machine Learning Perspective*. John Wiley & Sons.

Farrar, C.R. *et al.*, 1996. "Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: A literature review". *Los Alamos National Laboratory Report*.

Geng, X. *et al.*, 2018. "Research on fbg-based cfrp structural damage identification using bp neural network". *Photonic Sensors*.

Gomes, G.F., 2017. *Otimização da Identificação de Danos Estruturais por meio de Inteligência Computacional e Dados Modais*. Ph.D. thesis, Universidade Federal de Itajubá.

Gomes, G.F., 2024. "Deep learning enhanced metamodel design based on reduced mode shapes for delamination identification in composite structures". *Mechanics of Advanced Materials and Structures*.

Gomes, G.F., Chaves, J.A.S. and de Almeida, F.A., 2020a. "An inverse damage location problem applied to as-350 rotor blades using bat optimization algorithm and multiaxial vibration data". *Mechanical Systems and Signal Processing*.

Gomes, G.F., Cunha Jr., S.S. and Ancelotti Jr., A.C., 2016a. "Damage detection in aeronautical profile by using frequency changes and optimization algorithms". *Journal of Computational Interdisciplinary Sciences*.

Gomes, G.F., Cunha Jr., S.S. and Ancelotti Jr., A.C., 2016b. "Structural damage localization in composite plates using finite element method and optimization algorithm". *Australian Journal of Basic and Applied Sciences*.

Gomes, G.F. and Giovani, R.S., 2020. "An efficient two-step damage identification method using sunflower optimization algorithm and mode shape curvature (msdbi–sfo)". *Engineering with Computers*.

Gomes, G.F. and Pereira, J.V.P., 2020. "Sensor placement optimization and damage identification in a fuselage structure using inverse modal problem and firefly algorithm". *Evolutionary Intelligence*.

Gomes, G.F. *et al.*, 2016c. "Damage detection in composite materials via optimization techniques based on dynamic parameters changes". *International Journal of Emerging Technology and Advanced Engineering*.

Gomes, G.F. *et al.*, 2017. "A numerical–experimental study for structural damage detection in cfrp plates using remote vibration measurements". *Journal of Civil Structural Health Monitoring*.

Gomes, G.F. *et al.*, 2018a. "An estimate of the location of multiple delaminations on aeronautical cfrp plates using modal data inverse problem". *The International Journal of Advanced Manufacturing Technology*.

Gomes, G.F. *et al.*, 2018b. "A multiobjective sensor placement optimization for shm systems considering fisher informa-

tion matrix and mode shape interpolation". *Engineering with Computers*.

Gomes, G.F. *et al.*, 2018c. "A review of vibration based inverse methods for damage detection and identification in mechanical structures using optimization algorithms and ann". *Archives of Computational Methods in Engineering*.

Gomes, G.F. *et al.*, 2018d. "Sensor placement optimization applied to laminated composite plates under vibration". *Structural and Multidisciplinary Optimization*.

Gomes, G.F. *et al.*, 2018e. "The use of intelligent computational tools for damage detection and identification with an emphasis on composites - a review". *Composite Structures*.

Gomes, G.F. *et al.*, 2019. "Optimized damage identification in cfrp plates by reduced mode shapes and ga-ann methods". *Engineering Structures*.

Gomes, G.F. *et al.*, 2020b. "Inverse structural damage identification problem in cfrp laminated plates using sfo algorithm based on strain fields". *Engineering with Computers*.

Gopalakrishnan S., Ruzzene M., H.S., 2011. "Application of the finite element method in shm". In *Computational Techniques for Structural Health Monitoring*, Springer.

Guan, X., Wang, Y. and He, J., 2017. "A probabilistic damage identification method for shear structure components based on cross entropy optimizations". *Entropy*.

Guemes, A. *et al.*, 2025. "Structural health monitoring by fiber optic sensors". *Sensors*.

Hossain, M.S. *et al.*, 2017. "Artificial neural networks for vibration based inverse parametric identifications: A review". *Applied Soft Computing*.

Ihesiulor, O.K. *et al.*, 2013. "Delamination detection with error and noise polluted natural frequencies using computational intelligence concepts". *Composites Part B: Engineering*.

Jafarkhani, R. and Masri, S.F., 2011. "Finite element model updating using evolutionary strategy for damage detection". *Computer-Aided Civil and Infrastructure Engineering*.

Karsh, P.K., Mukhopadhyay, T. and Dey, S., 2018. "Spatial vulnerability analysis for the first ply failure strength of composite laminates including effect of delamination". *Composite Structures*.

Katunin, A., Dragan, K. and Dziendzikowski, M., 2015. "Damage identification in aircraft composite structures - a case study using various non-destructive testing techniques". *Composite Structures*.

Khalid, S. *et al.*, 2024. "Advancements in physics-informed neural networks for laminated composites: A comprehensive review". *Mathematics*.

Khan, A. *et al.*, 2019. "Structural vibration-based classification and prediction of delamination in smart composite laminates using deep learning neural network". *Composites Part B*.

Khan, M. *et al.*, 2022. "Influence determination of damage to mechanical structure based on modal analysis and modal assurance criterion". *Vibroengineering PROCEDIA*.

Khodabandehlou, H., Pekcan, G. and Fadali, M.S., 2018. "Vibration-based structural condition assessment using convolution neural networks". *Structural Control and Health Monitoring*.

Magacho, E.G., Jorge, A.B. and Gomes, G.F., 2021. "Inverse problem based multiobjective sunflower optimization for structural health monitoring of three-dimensional trusses". *Evolutionary Intelligence*.

Mello, F.M.d.S., Pereira, J.L.J. and Gomes, G.F., 2024. "Multi-objective sensor placement optimization in shm systems with kriging-based mode shape interpolation". *Journal of Sound and Vibration*.

Nimje, Y.P., 2016. *Partial delamination detection and quantification in composite laminates using Laser Doppler Vibrometer*. Master's thesis, Indian Institute of Technology Hyderabad.

Ofir, Y. *et al.*, 2025. "Real-time damage detection in an airplane wing during wind tunnel testing under realistic flight conditions". *Sensors*.

Oliveira, T.L.L. *et al.*, 2024. "The role of non-destructive testing of composite materials for aerospace applications". *NDT*.

Oliver, G.A., 2021. *Wavelet transform-based damage identification in laminated composite beams*. Master's thesis, Universidade Federal de Itajubá.

Oliver, G.A., Ancelotti Jr., A.C. and Gomes, G.F., 2020. "Neural network-based damage identification in composite laminated plates using frequency shifts". *Neural Computing and Applications*.

Oliver, G.A. *et al.*, 2022. "The influence of delamination parameters on the wavelet based damage index in cfrp structures". *Mechanics of Advanced Materials and Structures*.

Owolabi, G.M., Swamidas, A.S.J. and Seshadri, R., 2003. "Crack detection in beams using changes in frequencies and amplitudes of frequency response functions". *Journal of Sound and Vibration*.

Padil, K.H. *et al.*, 2019. "Nonprobabilistic method to consider uncertainties in frequency response function for vibration-based damage detection using artificial neural network". *Journal of Sound and Vibration*.

Pant, S., Khodaei, Z.S. and Droubi, M.G., 2021. "Monitoring tasks in aerospace". In *Structural Health Monitoring Damage Detection Systems for Aerospace*, Springer.

Pereira, J.L.J. *et al.*, 2019. "The use of artificial intelligence in residual stress prediction in porous cfrp". In *Ibero-Latin American Congress on Computational Methods in Engineering*.

Pereira, J.L.J. *et al.*, 2020. "Lichtenberg optimization algorithm applied to crack tip identification in thin plate-like structures". *Engineering Computations*.

Pollock, L. *et al.*, 2021. "The need for aerospace structural health monitoring: A review of aircraft fatigue accidents". *International Journal of Prognostics and Health Management*.

Rahul, V. *et al.*, 2019. "Structural health monitoring of aerospace composites". In *Structural Health Monitoring of Biocomposites, Fibre-Reinforced Composites and Hybrid Composites*, Academic Press.

Raut, N.P., Kolekar, A.B. and Gombi, S.L., 2021. "Optimization techniques for damage detection of composite structure: A review". *Materials Today: Proceedings*.

Rocha, H., Semprimoschnig, C. and Nunes, J.P., 2021. "Sensors for process and structural health monitoring of aerospace composites: A review". *Engineering Structures*.

Rucevskis, S. *et al.*, 2016. "Mode shape-based damage detection in plate structure without baseline data". *Structural Control and Health Monitoring*.

Sause, M.G.R. and Jasiūnienė, E., eds., 2021. *Structural Health Monitoring Damage Detection Systems for Aerospace*. Springer.

Souza, P.R. and Nóbrega, E.G.O., 2016. "An effective structural health monitoring methodology for damage isolation based on multisensor arrangements". *Journal of the Brazilian Society of Mechanical Sciences and Engineering*.

Stepinski, T., Uhl, T. and Staszewski, W., 2013. *Advanced Structural Damage Detection: From Theory to Engineering Applications*. John Wiley & Sons.

Tavares, S.M.O. *et al.*, 2024. "Aircraft structural design and life-cycle assessment through digital twins". *Designs*.

Tributsch, A. and Adam, C., 2017. "An enhanced energy vibration based approach for damage detection and localization". *Structural Control and Health Monitoring*.

Vila, J.L.C.R. *et al.*, 2024. "Wavelet-based numerical investigation on damage localisation and quantification in beams using static deflections and mode shapes". *European Journal of Mechanics / A Solids*.

Wang, S., Yu, X. and Perdikaris, P., 2020. "When and why pinns fail to train: A neural tangent kernel perspective". *arXiv preprint arXiv:2007.14527*.

Xiang, J. and Liang, M., 2012. "A two-step approach for damage identification in plates". *Engineering Fracture Mechanics*.

Yin, T., Jiang, Q.H. and Yuen, K.V., 2017. "Vibration-based damage detection for structural connections using incomplete modal data by bayesian approach and model reduction technique". *Engineering Structures*.

Yuan, F.G., ed., 2016. *Structural Health Monitoring (SHM) in Aerospace Structures*. Woodhead Publishing / Elsevier.

Zang, C. and Imregun, M., 2001. "Structural damage detection using artificial neural networks and measured frf data reduced via principal component projection". *Journal of Sound and Vibration*.

Zhang, Z. *et al.*, 2018. "Vibration-based assessment of delaminations in frp composite plates". *Composites Part B*.

9. RESPONSABILIDADE AUTORAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

DAMAGE IDENTIFICATION IN COMPOSITES VIA ARTIFICIAL INTELLIGENCE: A REVIEW OF VIBRATION-BASED METHODS

Davi Toledo da Costa, dtcbsb@gmail.com[1]
Sergio Henrique da Silva Carneiro, shscarneiro@unb.br[2]

[1,2]College of Science and Technology in Engineering (FCTE), University of Brasília (UnB), 72444-240, Gama, DF, Brazil

Abstract: Composite materials play a central role in modern aerospace engineering due to their high specific strength and customizable stiffness. However, they exhibit complex failure mechanisms, such as delamination and matrix cracking, which are difficult to detect via traditional inspection methods and require aircraft downtime. In this scenario, Structural Health Monitoring (SHM) based on vibrational response emerges as a viable alternative for continuous diagnostics. Transitioning these technologies to operational applications faces challenges related to aviation certification and computational cost. The main objective of this work is to present a review of recent literature on the application of Artificial Intelligence and metaheuristics for composite damage identification using modal and vibration analysis. The research analyzed 85 papers, categorizing the literature into two main approaches: the inverse optimization problem formulation and pattern recognition via machine learning. The evaluation adopted criteria based on physical interpretability, computational cost, empirical data dependency, and robustness to operational variations. Results indicate that optimization methods offer high explainability but present prohibitive computational costs due to the severe non-convexity of the inverse problem. Conversely, purely data-driven methods provide low latency but suffer from their black-box nature (limiting certification) and exhibit performance degradation during empirical testing due to the Reality Gap associated with non-linear damping dynamics. The study suggests that technological advancement in the sector depends on the development of hybrid models, highlighting Physics-Informed Neural Networks (PINNs). It is demonstrated how PINNs incorporate structural dynamics equations into the training process, reducing reliance on experimental data and favoring interpretability, although they require algorithmic treatment for gradient instabilities, as described by the Neural Tangent Kernel (NTK) theory.

Keywords: Composite Materials, Damage Detection, Inverse Problem, Physics-Informed Neural Networks, Modal Analysis, Aviation Certification